



Sistema de Suporte à Decisão para Predição de Cargas e Modelagem de Dependência em Sistemas Elétricos de Potência

Cláudio A. Rocha², Ádamo L. de Santana¹, Carlos Renato L. Francês¹,
Liviane Rego¹, João C. W. A. Costa¹, Eloi Favero¹, Ubiratan Bezerra¹,
Vanja Gato³, Armando Tupiassú³

¹Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal do Pará - Campus Univ. do Guamá, Rua Augusto Côrrea, 01 - 66075-110 - Belém - PA - Brasil

²Centro Federal de Educação Tecnológica do Pará - Av. Almirante Barroso, 1155 - 66093-904 - Belém - PA e Centro de Ciências Exatas e Tecnologia - Universidade da Amazônia - Av. Alcindo Cacela, 287 - 66060-902 - Belém - PA - Brasil

³Rede Celpa - Av. Gov. Magalhães Barata, 209 - 66040-170 - Belém - PA - Brasil
alex@bcc.unama.br, {adamo, rfrances, liviane, jweyl, favero, bira}@ufpa.br,
{vanja.gato, armando.tupiassu}@redcelpa.com.br

Abstract. *One of the most desired aspects for power suppliers is the acquisition/sell of energy in a future time. However, power consumption forecast is not characterized only by the variables of the power system itself, being related to socio-economic and climatic factors. This way, it is essential for the power suppliers to project and correlate these parameters. This paper presents a system for power supply forecasting based on time series methods, with the purpose of defining the future power consumption of a given region. The system also provides the establishment of correlations among the variables using bayesian networks.*

Resumo. *Um dos pontos almeçados por concessionárias do setor elétrico é a capacidade de planejamento de aquisição/venda de energia elétrica em um tempo futuro. Entretanto, predições de consumo de energia não são função apenas de fatores do próprio sistema elétrico, estando relacionados a aspectos sócio-econômicos e climáticos. Assim, é fundamental para as concessionárias projetar e correlacionar os parâmetros supracitados. Este artigo apresenta um sistema para predição de cargas elétrica baseado em métodos de séries temporais, com a finalidade de definir qual o consumo de energia futuro de uma dada região. Adicionalmente, o sistema possibilita o estabelecimento de correlações de grandezas utilizando redes bayesianas.*

1. Introdução

A previsão de carga (carga elétrica em MW) é uma estratégia primordial dos sistemas elétricos, e é baseada nessa previsão que se planejam e operam esses sistemas de forma confiável e segura [Douglas et al 1998] [Senjyu et al 2002]. Tipicamente, em previsão de carga, pretende-se definir qual o consumo de energia futuro de uma dada região de modo, por exemplo, a projetar ou adequar o sistema elétrico para atender esses

consumidores, quando essas demandas se concretizarem no futuro. Além disso, utilizando as prospecções propostas neste trabalho, as concessionárias de energia elétrica podem estimar de maneira satisfatória a compra de energia baseada na demanda futura e nas relações de preços apresentados pelos fornecedores do Brasil, o que pode levar a uma economia financeira substancial em função da diminuição da diferença entre a quantidade de energia comprada e consumida.

Em qualquer situação, a previsão de carga deve manipular dados históricos de cargas elétricas (em MW) registrados em seus bancos de dados. Então, como entrada básica dos estudos tem-se os dados históricos de cargas, obtidos em intervalos de coleta convenientes. Esses dados são influenciados por diversas outras variáveis exógenas aos sistemas elétricos, como a temperatura, umidade e até mesmo sócio-econômicas, como arrecadação, variação do número de empregos gerados em determinados setores da economia, entre outros. Desta forma, alguns desses fatores fazem parte dos dados de entrada dos modelos propostos neste artigo – predição de consumo e modelagem das correlações que este consumo tem com os fatores climáticos e sócio-econômicos.

O trabalho aqui descrito originou-se a partir dos estudos propostos para o projeto de pesquisa “PREDICT - Ferramenta de Suporte à Decisão para Predição de Cargas de Sistemas Elétricos”, aprovado pela “Agência Nacional de Energia Elétrica do Brasil – ANEEL” e que está em curso desde setembro de 2004. Este projeto, realizado em parceria com o governo de estado do Pará e a Concessionária de Energia Elétrica do Estado do Pará (CELPA), visa, basicamente, projetar e implementar um sistema de suporte à decisão, utilizando métodos matemáticos e de inteligência computacional, para prever as necessidades de compra de energia no mercado futuro e para realizar inferências sobre a situação do sistema elétrico, a partir de dados históricos de consumo e suas correlações com dados climáticos e sócio-econômicos, o que pode contribuir também para a tomada de ações de maneira antecipada, baseada na exploração dos cenários que as redes bayesianas podem projetar.

Este artigo está organizado da seguinte maneira. Na seção 2, é abordada a utilização de métodos de regressão para predição de carga. Na seção 3, são apresentadas as redes bayesianas geradas para modelar as correlações entre consumo de energia e condições climáticas e sócio-econômicas do estado do Pará. Na seção 4, são explorados alguns resultados obtidos com aplicação dos modelos utilizados. Na seção 5, são apresentadas algumas considerações finais deste trabalho.

2. Predição de carga - séries temporais com regressão linear

Nesta seção, é apresentado o modelo de regressão linear utilizado para análise dos dados. O modelo foi utilizado de modo a verificar a tendência dos dados, examinando o passado para inferir sobre o seu comportamento futuro, possibilitando a realização de previsões.

Os dados disponíveis para análise são referentes à energia requerida para todo o estado do Pará. Esses dados dizem respeito ao consumo total de energia no estado, em um determinado município e/ou em uma determinada classe de consumo (residencial, industrial, comercial, rural, poder público, iluminação pública, serviço público e consumo próprio), no decorrer de um determinado período. Para efeito de estudo de

caso, foram utilizados os dados relativos à energia requerida no período de janeiro de 1991 a dezembro de 2005, como é apresentado no gráfico da Figura 1.

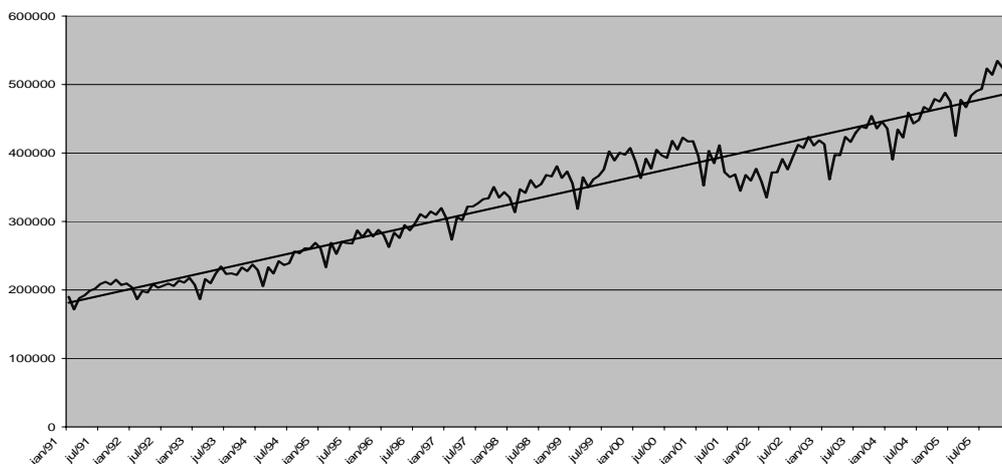


Figura 1. Histórico do consumo de energia de Jan/91 a Dez/05.

Pela observação do gráfico da Figura 1, resultante do histórico dos dados fornecidos pela concessionária de energia elétrica, pode ser verificada a existência de uma tendência, caracterizando-se, como apresentado a seguir, por meio de correlogramas, como uma série não-estacionária.

Pela Figura 2, pode ser constatada a não-estacionariedade da série, não só em nível, mas também que a mesma não se torna estacionária em consecutivas diferenciações (Figura 3).

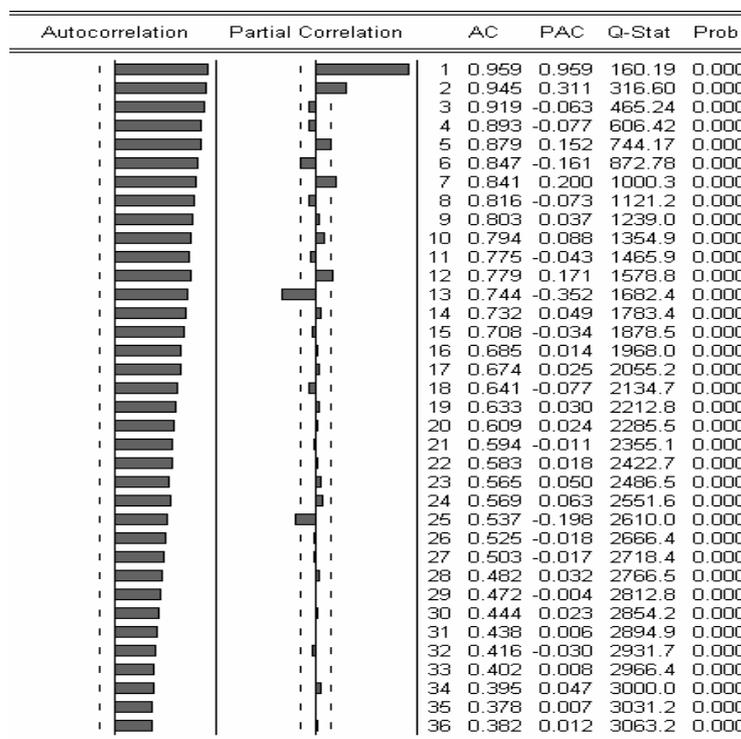


Figura 2. Correlograma em nível da série.

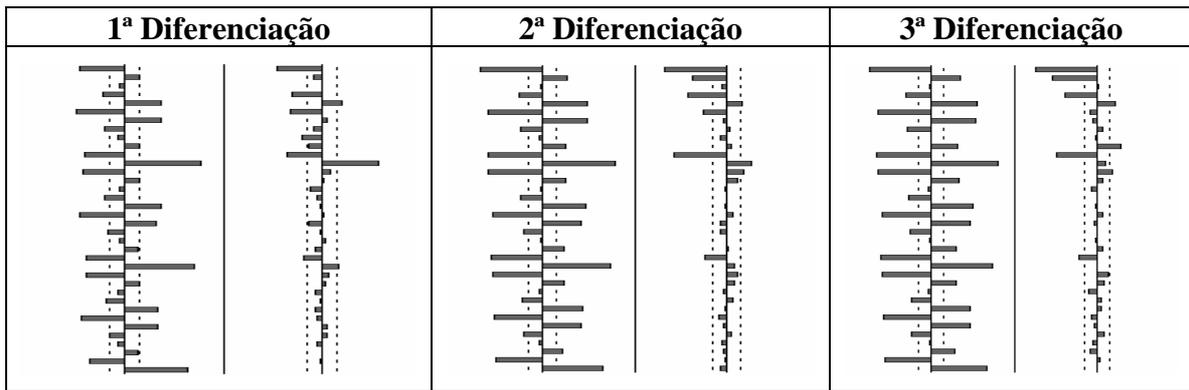


Figura 3. Autocorrelação e Correlação Parcial da 1ª, 2ª e 3ª diferenciação da série.

Uma vez verificado pelo seu comportamento que os dados tratam de uma série “explosiva”, e que a mesma não atingia uma estacionariedade, observando-a como um todo, utilizou-se uma nova abordagem. Desta feita, seccionando a série única de dados, antes mensal, em 12 séries anuais, correspondentes aos meses de janeiro a dezembro.

Partindo dessa abordagem, as séries foram então analisadas, apresentando agora, como pode ser visto pelos correlogramas da Figura 4, uma estacionariedade.

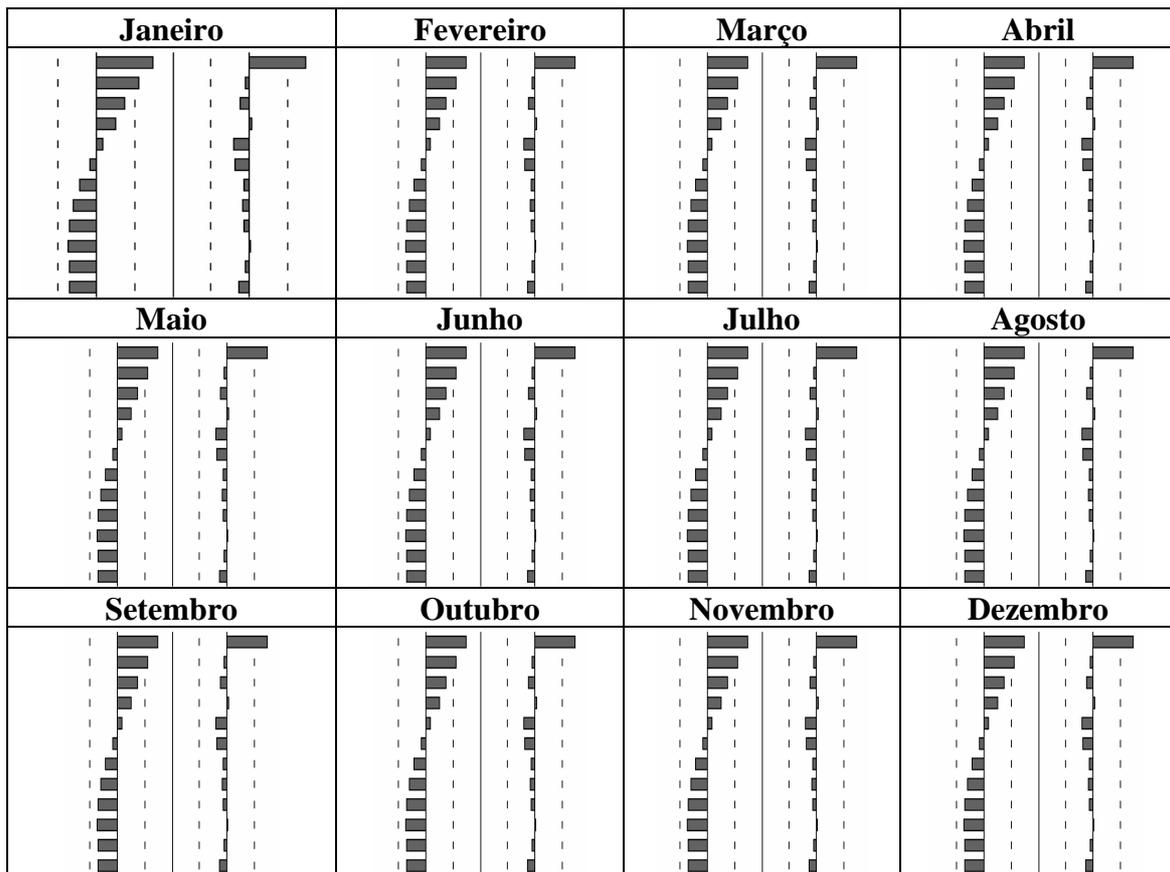


Figura 4. Autocorrelação e Correlação Parcial dos dados nos meses de Janeiro a Dezembro.

A solução do modelo linear utilizado, de modo a realizar a predição da série de dados para momentos futuros, é obtida segundo o modelo dos mínimos quadrados

ordinários, assumindo as restrições do teorema de Gauss-Markov (ver [Gill 2002], [Pindick e Rubinfeld 2004], [Guajarati 1995]); convergindo o modelo de regressão então para um melhor estimador linear não tendencioso (*Best Linear Unbiased Estimator* - BLUE).

O modelo linear pode ser expresso segundo a equação (1).

$$Y_t = \alpha + \beta T_t + \varepsilon_t (1)$$

Onde:

Y_t é o valor da variável no período t ;

α é o intercepto da regressão;

β é o coeficiente de tendência da regressão;

T_t é valor da variável de tempo no período t ;

ε_t é o termo de erro aleatório.

A Figura 5 apresenta o gráfico referente ao histórico da série, agora separado mês a mês.

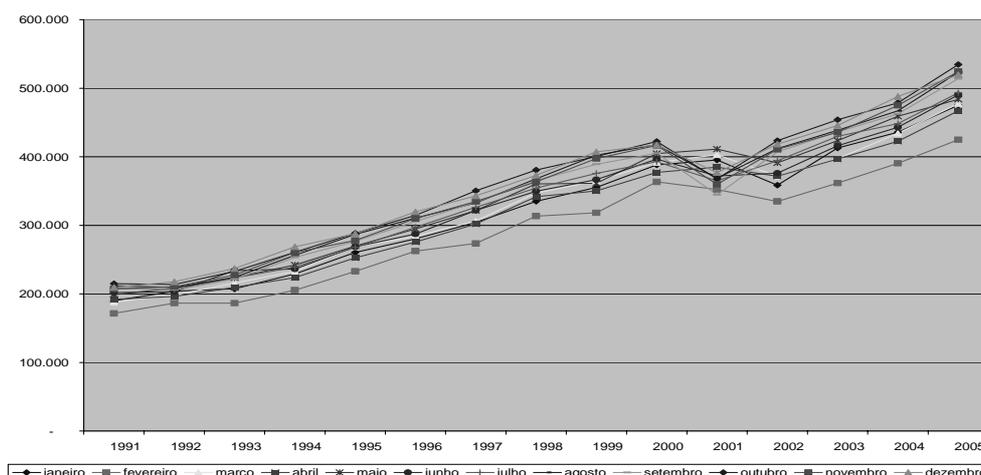


Figura 5. Histórico do consumo de energia de 1991 a 2005 separado mês a mês.

A partir da Figura 5, é possível observar um crescimento linear das séries no decorrer do tempo, com exceção do período que vai de 2001 a 2002, caracterizado pela ocorrência da medida de racionamento de energia nacional [ANEEL 2003].

Para calcular a taxa de crescimento da série, de modo a poder-se verificar o seu comportamento futuro, foi trabalhado o modelo da taxa geométrica de crescimento (2).

$$Y_t = Y_0 (1 + r)^t (2)$$

Onde:

Y_0 é o valor da variável no período inicial;

r é a taxa de crescimento.

Tomando o logaritmo natural em ambos os lados da equação (2), tem-se (3):

$$\ln Y_t = \ln Y_0 + t \ln(1 + r) \quad (3)$$

que pode ser reescrita como (4), tomando-se $\alpha = \ln Y_0$ e $\beta = \ln(1 + r)$.

$$\ln Y_t = \alpha + \beta T + \varepsilon_t \quad (4)$$

A taxa de crescimento fica então em função da variável β , que por sua vez é calculada segundo (5):

$$\beta = \frac{n \cdot \sum (Y \cdot T) - \sum Y \cdot \sum T}{n \cdot \sum T^2 - (\sum T)^2} \quad (5)$$

A partir dos dados existentes (Jan/91 a Dez/05), foi primeiramente realizada uma análise utilizando apenas os dados referentes ao intervalo até o ano de 2004 (Jan/91 a Dez/04), realizando com base nos mesmos uma estimação da seqüência dos seus valores para o ano de 2005, de modo assim a verificar a confiabilidade do estimador para em seguida realizar uma projeção do seu comportamento para o ano de 2006.

De posse das equações, as taxas de crescimento são então calculadas para cada uma das 12 séries, permitindo assim a estimação em cada série para um ponto no futuro.

Os resultados obtidos aqui pela aplicação do modelo de regressão, assim como a sua significância, serão melhor analisados na seção 4.

3. Redes bayesianas para a medida das correlações de consumo, condições climáticas e sócio-econômicas.

As redes bayesianas podem ser entendidas como modelos que codificam os relacionamentos probabilísticos entre as variáveis que representam um determinado domínio [Russel e Norvig 2003]. Esses modelos possuem como componentes uma estrutura qualitativa, representando as dependências entre os nós, e quantitativa (tabelas de probabilidades condicionais - TPCs desses nós), avaliando, em termos probabilísticos, essas dependências [Chen 2001], [Korb 2003]. Juntos, esses componentes propiciam uma representação eficiente da distribuição de probabilidade conjunta do conjunto de variáveis X de um determinado domínio [Pearl 1988]. A distribuição conjunta é dada por (6):

$$P(X) = \prod_{i=1}^n P(X_i | Pa_i) \quad (6)$$

na qual Pa_i são os nós-pais do nó X_i . Essa representação acarreta uma redução substancial do número de probabilidades a serem manipuladas, a partir da utilização do conceito de independência condicional, expressa por esta equação.

A escolha das redes bayesianas para a construção do Sistema apresentado neste trabalho deveu-se principalmente a semântica deste modelo, a qual facilita, dada a inerente representação causal dessas redes, o entendimento e o processo de tomada de decisão, por parte dos usuários desses modelos [Korb 2003]. Isto se deve, basicamente, ao fato das relações entre as variáveis do domínio poderem ser visualizadas

graficamente, além da quantificação, em termos probabilísticos, dos efeitos dessas relações.

3.1. Pré-processamento dos Dados

A base de dados, que foi utilizada para a geração das redes bayesianas, foi concebida a partir dos dados de energia requerida e de consumo fornecidos pela Concessionária de Energia do Estado do Pará (CELPA), os dados climáticos fornecidos pelo Instituto Nacional de Pesquisas Espaciais (INPE) e os dados sócio-econômicos fornecidos pelo Governo do Estado do Pará, através de sua Secretaria Executiva de Estado de Planejamento, Orçamento e Finanças (SEPOF). Em razão do interesse dos envolvidos no projeto *Predict* pela análise dos dados de energia em períodos mensais, e do mesmo modo que o proposto na seção 2, as análises foram feitas utilizando estes períodos.

Dessa forma, os dados para os aspectos climáticos e sócio-econômicos, também foram arranjados desse modo, a partir de suas médias mensais, no caso dos primeiros e no acumulado do mês, no caso dos últimos. Ressalta-se, ainda, que todo o processo de extração de padrões dos dados está sendo acompanhado pelos especialistas do domínio e que a construção das tabelas utilizadas, também adota esse princípio, considerando os componentes *consumo*, *climáticos* e *sócio-econômicos*, especificados a seguir:

- *Componente Consumo*: contém os dados relativos à energia requerida e ao consumo por mês, além dos dados de consumo por município e por classe de consumo.
- *Componente Climático*: composto pelos dados relativos às médias mensais de umidade relativa, temperatura máxima e mínima e índice pluviométrico dos 14 municípios em que há pontos de coleta do INPE no estado do Pará.
- *Componente Sócio-Econômico*: constituído pelos dados de arrecadação, evolução do emprego formal, índices inflacionários, número de constituições e extinções de empresas em alguns setores da economia (ex: construção civil, indústria de transformação e agropecuária), totalizando 25 atributos. Com base nas interações com os especialistas e na utilização de técnicas de seleção de *features*, baseadas em métodos bayesianos, foram considerados apenas quatro atributos – cotação do dólar, arrecadação total do estado, número de contratações de pessoal no setor de indústria de transformação e o número de contratações no setor agropecuário, os quais tinham maior impacto na variação de consumo de energia no Pará.

Para atingir os objetivos propostos no projeto *Predict*, quanto às análises das dependências entre o consumo e os componentes climático e econômico, foi necessária a construção de diversos conjuntos de dados, a partir das tabelas originais, representadas pelos componentes supracitados. Considerou-se, ainda, para formulação desses conjuntos, a divisão dos dados por classe de consumo e município. Na Tabela 1, é apresentada a descrição dos conjuntos de dados utilizados para a modelagem de dependência no *Predict*.

Tabela 1. Conjuntos de dados criados para a extração de padrões de influência climática e sócio-econômica sobre o consumo de energia elétrica.

Conjunto de Dados	Atributos	Observações
Consumo Total - Climático	Consumo total mensal de energia do estado do Pará e os atributos contidos no componente climático.	Como o estado do Pará não apresenta uma variação tão acentuada dos valores destes atributos nestes 14 pontos e em razão destes pontos serem bem distribuídos pelo estado, foram também consideradas as médias desses valores para efeito de análise da influência climática no consumo total de energia em todo o estado.
Energia Requerida - Climático	Energia mensal requerida para o estado do Pará e os atributos contidos no componente climático.	Idem Consumo Total – Climático, considerando a energia requerida ao invés do consumo total.
Consumo por Classe - Climático	Energia consumida em todo o Pará, por classe de consumo, e os atributos contidos no componente climático.	Conjunto de dados criado com o intuito de medir a influência do clima sobre cada classe de consumo.
Consumo por Classe - Climático – Município M	Energia consumida no município M, por classe de consumo, e os atributos contidos no componente climático.	Foram criados 14 conjuntos de dados objetivando medir a influência do clima sobre cada classe de consumo nos municípios em que há ponto de coleta do INPE.
Consumo Total – Sócio-Econômico	Consumo total mensal de energia do estado do Pará, e os atributos contidos no componente sócio-econômico.	Como a SEPOF só disponibilizou o registro dos dados sócio-econômico totais do estado do Pará, não foram realizadas as inferências por município.
Energia Requerida – Sócio-Econômico	Energia mensal requerida para o estado do Pará, e os atributos contidos no componente sócio-econômico.	Idem Consumo Total – Sócio-Econômico, considerando a energia requerida ao invés do consumo total.
Consumo por Classe – Sócio-Econômico	Energia consumida em todo o Pará, por classe de consumo, e os atributos contidos no componente sócio-econômico.	Conjunto de dados criado com o intuito de medir a influência dos atributos sócio-econômicos sobre cada classe de consumo.

A partir da Tabela 1, é possível perceber que foram criados ao todo 20 conjuntos de dados. Vale enfatizar que o pré-processamento destes dados seguiu processos bastante criteriosos, principalmente relacionados ao emprego dos métodos de seleção, integração e limpeza, considerando-se os vários formatos adotados pelas fontes de dados (CELPA, SEPOF e INPE) utilizadas para a construção dos conjuntos de dados submetidos ao processo de modelagem de dependências.

3.2. Extração de padrões

Após a preparação e construção dos conjuntos de dados, os mesmos foram submetidos ao *PredictBayes*. Esse software, desenvolvido para fazer parte do sistema de suporte à decisão - *Predict*, é uma ferramenta capaz de construir a estrutura da rede bayesiana e calcular os parâmetros (probabilidades), a partir de uma base de dados. O principal objetivo do *PredictBayes* é prover a extração de conhecimento de base de dados na forma de redes bayesianas, bem como as respectivas probabilidades condicionais entre as variáveis dessas redes. O *PredictBayes* implementa um *algoritmo de propagação orientado a metas* que pode ser utilizado para apoiar um processo de tomada decisão

quantificado através de probabilidades. Este algoritmo é baseado no método de árvore de junção, proposto por Jensen [Jensen e Jensen 1994].

3.3. Redes bayesianas geradas

Para o aprendizado do modelo gráfico da rede bayesiana, ou seja, para o aprendizado das relações existentes entre as variáveis, o *PredictBayes* implementa o algoritmo de busca e pontuação K2 [Cooper e Herskovitz 1992], que permite encontrar a mais provável estrutura de rede de crença B_s a partir de um determinado conjunto de dados D . O algoritmo K2 aplica a pontuação bayesiana segundo (7).

$$P(B_s | D) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(r_i)}{\Gamma(r_i + N_{ij})} \prod_{k=1}^{r_i} \Gamma(N_{ijk} + 1) \quad (7)$$

Onde:

n é o número de nós;

q_i é o número de configurações dos pais da variável X_i ;

r_i é o número de possíveis valores do nó X_i ;

N_{ijk} é o número de casos em D onde o atributo X_i é instanciado com o seu valor k ,

e a configuração dos pais de X_i é instanciada com o valor j ;

N_{ij} denota o número de observações em que a configuração dos pais de X_i é instanciada com o valor j , sendo $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$.

A partir do uso desse método, foi gerada uma rede bayesiana para cada um dos 20 conjuntos de dados. Após a geração das redes bayesianas, foi utilizado o algoritmo de propagação do *PredictBayes* para efetuar inferências sobre essas redes. Para exemplificar as redes bayesianas resultantes, bem como essas inferências, considere as redes bayesianas geradas a partir dos conjuntos de dados Consumo Total – Sócio-Econômico e Consumo por Classe – Climático – Município_Oriximiná (Figura 6 e 7).

A partir da Figura 6, é possível visualizar as correlações entre as variáveis climáticas e o consumo total de energia no Pará, além das probabilidades marginais que, por questão de simplificação, são apresentadas apenas de algumas variáveis da rede.

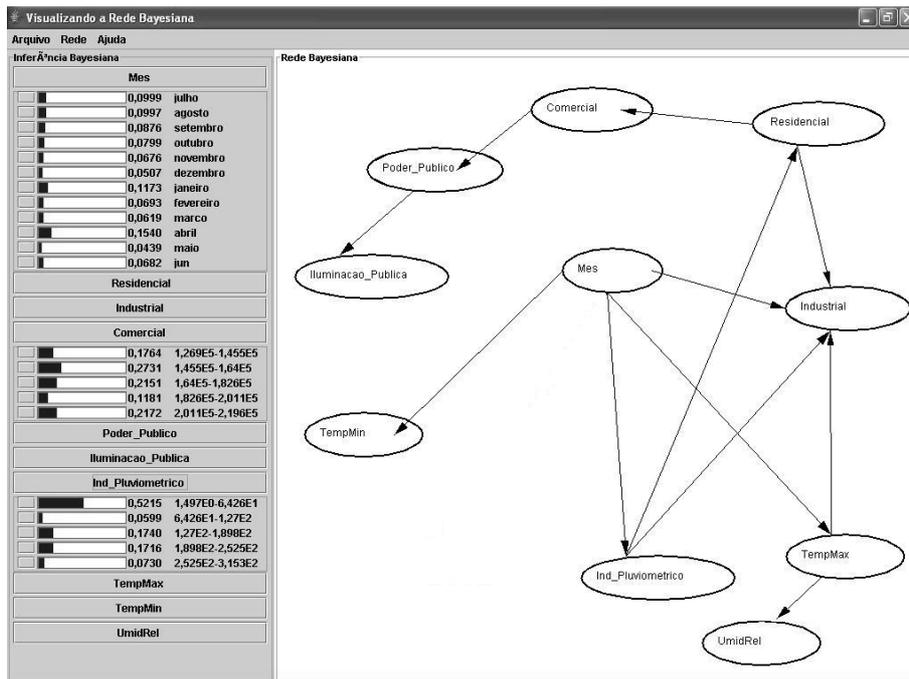


Figura 6. Rede bayesiana gerada a partir do conjunto de dados Consumo Total – Sócio-Econômico.

Na Figura 7, poderia ser realizada, por exemplo, a seguinte inferência: qual a probabilidade de o consumo está na maior faixa (o 5º estado da variável Consumo_Total), dada a evidência de que o aumento do número de contratações no setor agropecuário ficou dentro da faixa 2.113 a 2725 (o 4º estado da variável Agropecuario)? A resposta a essa questão é observada no valor de probabilidade apresentado para a faixa de maior consumo de energia (40,74%).

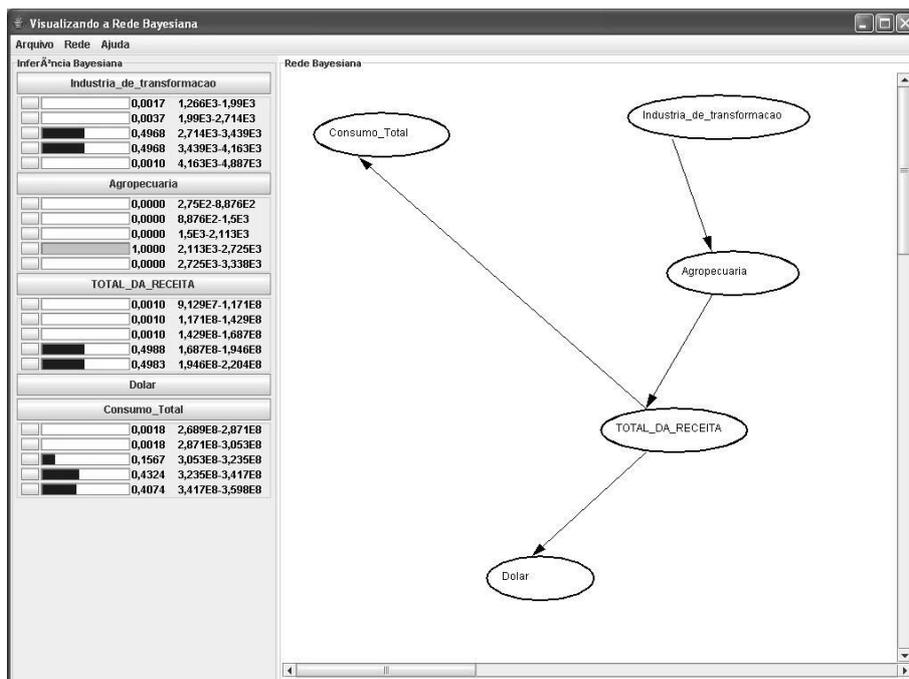


Figura 7. Rede bayesiana gerada a partir do conjunto de dados Consumo por Classe – Climático - Oriximiná

É possível, a partir das prospecções (inferências) sobre as redes bayesianas obtidas, apresentar aos usuários de níveis decisórios os diversos cenários que podem promover variações no consumo de energia elétrica, dadas as condições climáticas e sócio-econômicas do estado do Pará. Esta análise pode colaborar consideravelmente com o processo de análise das demandas de energia, o que pode levar à tomada de ações de maneira antecipada e conseqüentemente a diminuição dos custos de operação do sistema.

4. Avaliação dos resultados obtidos

A avaliação dos resultados obtidos com a aplicação dos métodos matemáticos e de inteligência computacional foi realizada considerando dois aspectos: previsão de carga com o uso de métodos de regressão e visualização e modelagem das Dependências, que serão detalhados a seguir.

4.1 - Previsão de Carga com o uso de Métodos de Regressão

A partir destes métodos, foram realizados estudos de prospecção de modo a prever os valores de consumo de energia.

Como especificado na seção 2, foi inicialmente realizada uma estimação dos valores de consumo para o ano de 2005, com base no intervalo de dados de Jan/91 a Dez/04. O resultado obtido pela estimação apresentou um erro de aproximadamente 1,47%, valor considerado não só aceitável, mas também inferior aos obtidos pelos métodos estatísticos utilizados pela Concessionária de Energia Elétrica, que giram em torno 4,0%. Essa diminuição do erro representa, evidentemente, uma considerável economia na compra de energia no mercado futuro.

Uma análise de predição com a utilização de outra técnica foi também realizada, de modo a caracterizar um estudo comparativo com os métodos de regressão, desta vez utilizando redes neurais [Haykin 1998].

A rede neural utilizada neste estudo foi uma rede feed-forward multicamada com duas camadas ocultas compostas por 8 neurônios na primeira camada e 6 na segunda, e usando como algoritmo de aprendizado o backpropagation adaptativo.

Os dados da série temporal foram submetidos como os vetores de entrada da rede neural de duas formas: como uma única série mensal e como séries anuais, como descrito na seção 2. Os resultados são apresentados pela rede neural, com os dados mensal e anuais, comparando-os com os dados reais (Figura 8).

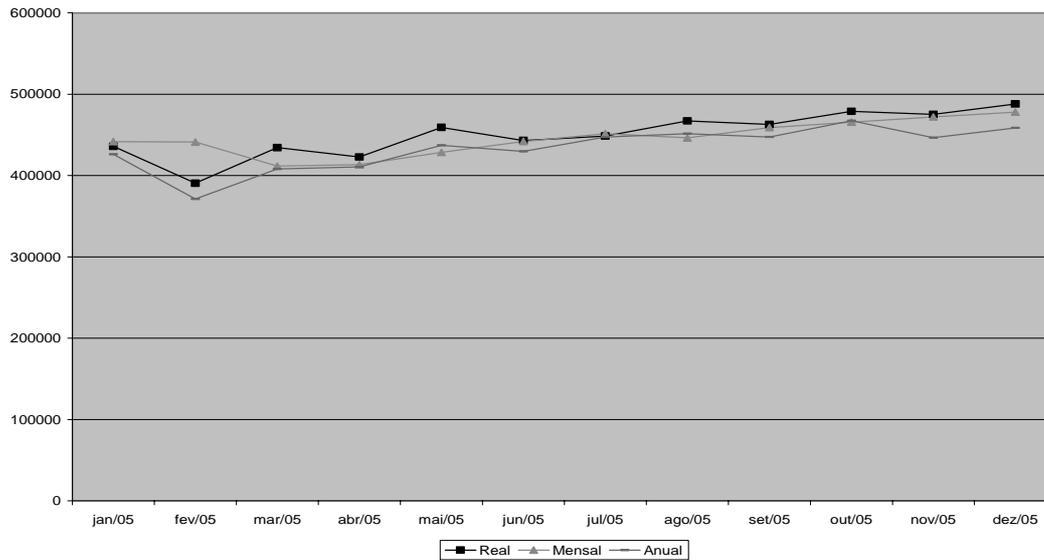


Figura 8. Valores reais do consumo de energia (Jan/05 to Dez/05) e seus valores estimados pelas redes neurais para as series temporais utilizando as abordagens mensal e anuais.

Os resultados obtidos pelas redes neurais apresentaram um erro aproximado de 4,13% e 4,08% para as séries temporais submetidas como mensal e anuais, respectivamente, valor que, como mencionado anteriormente, fica em torno da mesma taxa de erro já alcançada pela concessionária de energia elétrica, provando que o modelo de estimação baseado nos métodos de regressão é bem mais eficiente para este caso.

Uma vez verificada a efetividade do modelo de estimação, baseado em regressão, para a série de dados, foi feita uma projeção do seu comportamento para o ano de 2006, como pode ser visto na Figura 9.

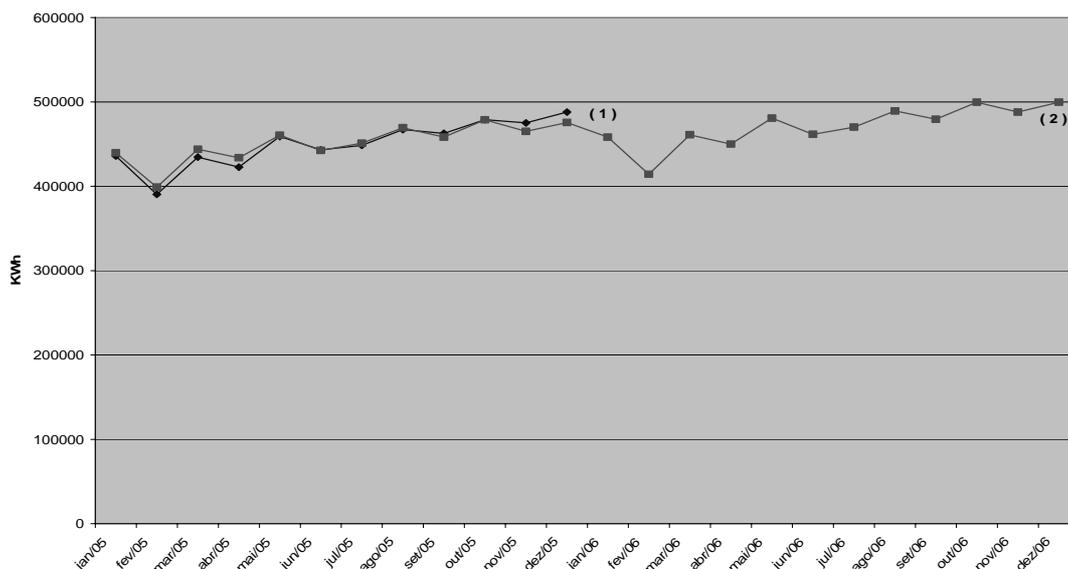


Figura 9. (1)Valores reais de Jan/05 a Dez/05 e (2) estimados de Jan/05 a Dez/06 do consumo de energia.

Destaca-se, ainda, que estes resultados foram obtidos mesmo na presença de um longo período de consumo anômalo de energia (entre 2001 e 2002), ocorrido pela medida de racionamento de energia em todo o território brasileiro (coloquialmente chamado de “apagão”).

4.2 - Visualização e modelagem das dependências

A correlação entre as variáveis de estudo possibilita (graficamente) a visualização, na forma de redes bayesianas, das dependências entre os parâmetros dos componentes consumo, climático e econômico da base de dados fornecida e a quantificação dessas dependências em termos de probabilidades.

A avaliação dos resultados obtidos foi realizada a partir dos próprios recursos do *PredictBayes*, com a supervisão do especialista no domínio. Assim, foi utilizado o próprio ambiente gráfico desta ferramenta para verificar as dependências entre os nós das redes bayesianas. Por exemplo, a partir da rede bayesiana da Figura 6, é possível analisar as dependências entre os nós, bem como quantificar essas dependências, consultando as probabilidades condicionais, marginais, verossimilhança e variância.

A aplicação do algoritmo de propagação, provido pelo *PredictBayes*, possibilitou efetuar uma série de inferências sugeridas pelo especialista. Assim, o caráter exploratório das redes bayesianas propiciou, por meio da informação de evidências para alguns valores (estados) das variáveis do domínio, a verificação, de forma bastante interativa, das várias situações de interesse. A seguir, são apresentados alguns exemplos das análises realizadas:

- O Diagnóstico da influência dos fatores econômicos e climáticos sobre o consumo de energia elétrica. As inferências realizadas permitiram que os especialistas do domínio pudessem visualizar, em termos quantitativos, desde influências mais simples de perceber, como a que o aumento de temperatura causa um proporcional aumento de consumo, até aquelas não tão triviais como a influência que o aumento do número de contratações no setor agropecuário exerce sobre este consumo;
- A classe de consumo residencial é a que sobre maior influência da ação das chuvas. Em comparação com as classes industrial e comercial, por exemplo, o impacto do aumento do índice pluviométrico sobre o consumo residencial é, em média, 12% maior que sobre o consumo dessas duas classes.
- Uma vez que a economia do Pará é fortemente voltada para os setores extrativista e agropecuário, foi possível verificar que a influência do aumento do nível de emprego no setor agropecuário sobre o consumo na classe industrial é maior que a elevação do nível de emprego na indústria de transformação sobre esta classe de consumo.

Em razão da interface amigável e da facilidade de compreensão dos modelos (redes bayesianas) gerados, foi possível verificar a eficiência do método de aprendizado utilizado, no auxílio à tomada de decisão por parte dos envolvidos no projeto *Predict*. Prova disto, foi a utilização de alguns resultados preliminares deste trabalho para investigação da correlação das informações de consumo e das condições climáticas e sócio-econômicas de outros estados brasileiros (Mato Grosso e Tocantins), atendidos

pelo mesmo grupo de empresas do qual faz parte a concessionária de energia elétrica do Pará.

Além disso, é possível perceber os diversos diagnósticos das relações entre o consumo e os aspectos econômicos e climáticos do estado do Pará que podem ser realizados pelos usuários do sistema de suporte à decisão proposto, o que, aliado ao seu módulo de predição, permitem acompanhar e medir os impactos das mudanças dos cenários climáticos e de determinados setores da economia no consumo de energia.

5. Considerações Finais

A intenção da realização dos estudos propostos é diagnosticar as relações entre o consumo e aspectos econômicos e climáticos do estado do Pará, bem como efetuar predição de consumo de energia. Assim, é possível disponibilizar um sistema de suporte à decisão para os gestores, tanto da Concessionária de Energia, que podem estabelecer contratos mais vantajosos de energia no mercado futuro e analisarem os cenários favoráveis, com base nas variações climáticas e das condições sócio-econômicas de uma determinada região, quanto para os usuários de nível decisório dos órgãos de governo, em razão de poderem estabelecer políticas e investimentos para o desenvolvimento de determinada região do estado.

Diante desse panorama, a principal contribuição deste trabalho foi aplicar o processo de extração de padrões de consumo de energia, com o objetivo de prever o consumo de energia e, conseqüentemente, estabelecer contratos mais vantajosos de compra de energia no mercado futuro para as concessionárias de energia elétrica, bem como prover aos gestores de governo, em parceria com essas concessionárias, subsídios para a formulação de programas governamentais de inclusão social de acordo com as condições sócio-econômicas de determinada região, haja vista que a expansão do fornecimento de energia, principalmente em se tratando da região amazônica, que possui ainda muitas áreas sem energia firme, é fator preponderante de desenvolvimento.

Os resultados preliminares obtidos encorajam fortemente o uso das técnicas utilizadas. Isto pode ser atestado pelo interesse gerado na comunidade de concessionárias (gestores e/ou especialistas) em conhecer e analisar o que foi proposto neste trabalho. Os métodos utilizados para a elaboração do sistema de suporte já estão sendo aplicados nas concessionárias de Mato Grosso e Tocantins e alguns resultados satisfatórios já estão sendo obtidos.

Naturalmente, outros estudos de prospecção precisam ser realizados (tais como: análise de fatores como segurança do sistema e qualidade da energia suprida aos consumidores). Além disso, novas grandezas podem ser incluídas para análise do impacto das variáveis sócio-econômicas no consumo de energia. Poderia ser analisado, dentre outros aspectos, qual a variação do consumo de energia residencial e/ou comercial, quando ocorre uma elevação acentuada, por exemplo, na produção de cimento, bem como o impacto das exportações no consumo total de energia elétrica, haja vista que o Pará é um grande exportador de riquezas, principalmente de minérios. Estas investigações fazem parte da próxima etapa do projeto *Predict*.

Agradecimentos

Os autores gostariam de agradecer aos financiadores do projeto que fundamenta este artigo: CAPES, CNPq, ANEEL/Rede Celpa.

Referências Bibliográficas

- ANEEL. (2003). “Atlas de energia elétrica do Brasil”, Agência Nacional de Energia Elétrica, Brasília, DF.
- Chen, Z. (2001). “Data Mining and Uncertain Reasoning - an Integrated Approach”, John Wiley Professional.
- Cooper, G., Herskovitz, E. (1992). “A Bayesian Method for the Induction of Probabilistic Networks from Data”. *Machine Learning*, 9, p. 309-347.
- Douglas, A.P. Breipohl, A.M. Lee, F.N. Adapa, R. (1998). “The impacts of temperature forecast uncertainty on Bayesian loadforecasting”. *IEEE Transactions on Power Systems*, vol. 13.
- Gill, J. (2002). “Bayesian Methods: A Social and Behavioral Sciences Approach”, Chapman & Hall/CRC.
- Guajarati, D. N. (1995). “Basic Econometrics”, McGraw-Hill.
- Haykin, S. (1998). “Neural networks: a comprehensive foundation”, Prentice Hall.
- Jensen F. V., Jensen, F. (1994). “Optimal junction trees”, In *Proceedings of the 10th Conference on Uncertainty in Artificial Intelligence*, p. 360–366.
- Korb, K. B., Nicholson, A. E. (2003). “Bayesian Artificial Intelligence”. CRC PRESS.
- Pearl, J. (1988). “Probabilistic Reasoning in Intelligent System”, Morgan Kaufmann Publishers.
- Pindick, R. S. and Rubinfeld, D. L. (2004). “Econometric Models and Economic Forecasts”, Irwin/McGraw-Hill.
- Russel, S. Norvig, P. (2003). “Artificial Intelligence – A Modern Approach”. Prentice Hall.
- Senjyu, T., Takara, H., Uezato, K., Funabashi, T. (2002). “One-hour-ahead Load Forecasting Using Neural Network”, *IEEE Transactions on Power Systems*, vol. 17, no. 1.